

4

Segmentação de Imagens de Úlceras de Perna

Segmentação é o processo de subdividir uma imagem em partes ou objetos constituintes [GONZALEZ, 1993]. Neste trabalho a segmentação é utilizada com a finalidade de separar a região da imagem referente à úlcera das demais áreas. Como o objetivo final é avaliar a quantidade proporcional de cada tecido interno, a segmentação preparará as imagens para que esse processo seja efetuado em toda a área da ferida.

Entretanto, o processo de segmentação de tais imagens não se constitui de uma tarefa tão simples. Vários fatores, característicos dessas imagens, tornam tal tarefa difícil de ser realizada com sucesso em todas as imagens. Dentre esses fatores, pode-se citar a dificuldade que há em distinguir a região da úlcera, da pele ao seu redor. Em muitas imagens analisadas, a pele, próxima à borda das úlceras, mistura-se gradativamente com o interior da ferida, sendo que nesses casos, torna-se difícil determinar com precisão a sua borda. Além disso, algumas úlceras apresentam tantas deformações que, aliadas com a dificuldade de determinar sua borda, tornam o processo de segmentação por computador ainda mais complexo e mais sujeito a falhas. Além desses fatores, inerentes à natureza dessas imagens, soma-se a falta de padronização, do ponto de vista da visão computacional, com que foram realizadas as aquisições das imagens utilizadas neste trabalho.

As aquisições das imagens utilizadas nesta pesquisa foram feitas com uma câmera VHS comum, e foram realizadas sem as condições mínimas

necessárias de iluminação. Como consequência disso, as imagens apresentaram uma grande variação de iluminação quando comparadas com outras imagens do mesmo paciente, adquiridas em épocas diferentes. As imagens adquiridas foram digitalizadas em um computador Pentium 233 através de uma placa Miro modelo DC 30. Devido à baixa resolução da câmera, as imagens digitalizadas apresentaram uma resolução insatisfatória, agravada pela compressão de vídeo utilizada na digitalização. Na Figura 4.1 é possível observar uma imagem de úlcera de perna com todas essas características descritas: difícil definição da borda, aparência deformada e baixa qualidade de iluminação.



Figura 4.1 - Imagem de úlcera de perna apresentando as características descritas nos parágrafos anteriores: difícil definição da borda, aparência deformada e baixa qualidade de iluminação.

Para contornar os problemas decorrentes da aquisição, as imagens, antes de serem segmentadas, são submetidas a uma etapa de Pré-processamento.

4.1. Pré-processamento

Nessa etapa, dois algoritmos são utilizados com a finalidade de melhorar a qualidade da imagem de modo a tornar sua segmentação mais eficiente. Tais algoritmos são: calibração e mediana.

4.1.1. Algoritmo de Calibração

O estágio de calibração é extremamente necessário e importante, principalmente quando medições e características extraídas de uma imagem são comparadas com medições de outras imagens. Essas informações extraídas podem ser, por exemplo, níveis de intensidade, os quais podem sofrer alterações decorrentes das variações de iluminação de cada aquisição. Para realizar essa correção de forma a manter os níveis de iluminação sempre constantes, é necessário que haja um ponto de referência, que seja comum em todas as imagens, cujas características sejam conhecidas a priori. Se ocorrerem diferenças de iluminação de uma imagem para outra, essa referência pode ser utilizada para efetuar a devida correção. Mesmo para imagens coloridas, a calibração é importante se a informação das cores de diferentes imagens é comparada. A calibração pode, também, melhorar o desempenho dos algoritmos utilizados, já que as imagens utilizadas nas medições conterão pixels dentro de uma faixa de valores conhecida. Por exemplo, imagens calibradas de úlceras terão faixas de valores RGB semelhantes para o tecido de granulação.


A referência utilizada para calibrar as imagens pode ser um objeto puramente branco, como foi utilizado por Herbin e Jones, [HERBIN, 1990] [JONES, 1995], ou ainda, conter uma faixa de níveis de cinza completa, como a que foi utilizada por Berriss [BERRISS, 2000]. A referência utilizada neste trabalho trata-se de uma régua branca, presente em todas as imagens adquiridas. Em uma imagem no formato RGB, os valores referentes à cor

branca, ou a qualquer nível de cinza, possuem a seguinte propriedade: $R=G=B$. Se essa relação for falsa, o ponto analisado não é puramente branco, ou cinza. A área referente à régua é selecionada manualmente, indicando um retângulo na régua com o auxílio do mouse. Da amostra da régua é calculada a média de cada canal RGB. A calibração é realizada calculando-se a porcentagem necessária para elevar o valor de cada canal RGB do seu nível atual para o seu nível máximo de branco, $R=G=B=255$. Em seguida essa compensação é aplicada sobre a imagem. Dessa forma, a relação $R=G=B$ é obtida, pois a porcentagem de cada canal é calculada individualmente de acordo com sua defasagem, e as faixas de valores correspondentes a cada cor, ou tecido, são mantidas para todas as imagens. A equação 4.1 mostra como é feito o cálculo. Nessa equação, as duas fórmulas são calculadas para cada canal, representado pela sigla ch , presente sempre do lado direito de cada variável. Nas fórmulas, a variável Max_{ch} representa o valor máximo do canal ch , no caso 255 para todos; a variável S_{ch} armazena a porcentagem que irá regular o canal ch ; R_{ch} é a amostra da régua referente ao canal ch ; G_{ch} é o canal calibrado e F_{ch} a imagem original. A Figura 4.2 mostra o resultado do processo de calibração.

$$S_{ch} = \frac{Max_{ch}}{\frac{1}{MN} \sum_{y=0}^{M-1} \sum_{x=0}^{N-1} R_{ch}(x, y)} \quad G_{ch}(x, y) = F_{ch}(x, y) * S_{ch} \quad (4.1)$$



(a)



(b)

Figura 4.2 - (a) Imagem original antes da calibração com o retângulo na régua indicando a porção que será utilizada como referência. (b) Imagem calibrada.

4.1.2. Filtro da Mediana

O filtro da mediana [GONZALEZ, 1993], [LOW, 1991], [PARKER, 1994] foi utilizado com o propósito de eliminar o ruído presente na imagem introduzido na aquisição. Uma das características desse filtro é que ele elimina o ruído mantendo as bordas intactas [LOW, 1991]. O filtro da mediana, também pode contribuir para a diminuição da quantidade de cores presentes na imagem, tornando-as mais homogêneas e melhorando o desempenho do algoritmo de segmentação. Neste trabalho, o filtro foi aplicado individualmente sobre cada canal RGB utilizando janelamento de 5x5.

4.2. Segmentação

Os modelos de segmentação adotados neste trabalho baseiam-se em algoritmos que operam sobre imagens em tons de cinza, ou intensidade. Os algoritmos para segmentação de imagens em tons de cinza são bem mais simples, rápidos e possuem uma literatura extensa, motivos pelos quais foram adotados neste trabalho. Embora as imagens utilizadas sejam coloridas, os algoritmos não serão aplicados diretamente sobre elas, mas em determinados canais que as compõem. No decorrer das pesquisas, foi constatado que o algoritmo de segmentação apresentava resultados que variavam muito de uma imagem para outra quando estas eram segmentadas por um canal em comum. Por exemplo, algumas imagens apresentavam um bom resultado quando segmentadas utilizando o canal de saturação do modelo HSI, enquanto que outras apresentavam resultados desencorajadores quando segmentadas pelo mesmo canal. Foi constatado então que o canal de níveis de cinza ideal para segmentar todas as imagens simplesmente não existia, pois este poderia variar de uma imagem para outra. Essa variação pode ser decorrente das diferentes condições de iluminação bem como de características da própria superfície das feridas. Dependendo do aspecto de cada úlcera, sua superfície pode apresentar uma aparência mais opaca ou

mais brilhante com reflexos especulares; que é o caso de feridas com exsudato.

Para contornar esse problema, a etapa de segmentação foi dividida em quatro seções: obtenção do canal ideal para segmentação, aplicação do algoritmo de segmentação, algoritmo de abertura (*opening*) e algoritmo de rotulação (*labeling*) para eliminar os objetos indesejados.

4.2.1. Escolha Automática do Canal Ideal para Segmentação

O algoritmo de escolha automática avalia seis canais, os quais são provenientes dos modelos RGB e HSI. Para realizar tal análise, é necessário que o operador do software selecione uma região retangular dentro da ferida, ou do objeto que se deseja segmentar, e outras três na parte externa. A partir dessas amostras, o algoritmo avalia três características que determinarão o melhor canal para ser usado na segmentação. As características são: iluminação do fundo, iluminação do objeto a ser segmentado e contraste entre o fundo e o objeto. O canal, ou imagem ideal para ser segmentado é aquele onde o fundo possui iluminação uniforme, o objeto possui iluminação uniforme, e o objeto e o fundo possuem bom contraste entre si. O algoritmo escolhe o canal cujas características se aproximam mais das que seriam as ideais.

Para extrair os valores numéricos dessas características, são utilizadas as amostras selecionadas pelo usuário do software, onde, sobre essas amostras, são realizados os cálculos descritos em seguida.

4.2.1.1. Média do Fundo e da Úlcera

Para o cálculo da média do fundo, a média individual de cada amostra é calculada primeiramente. Em seguida, é calculada a média das médias

resultantes de cada amostra. Se o cálculo da média do fundo fosse feito considerando as três amostras (ou n amostras) como sendo uma única imagem, o resultado dessa média levaria a interpretações equivocadas quando fosse realizado o cálculo do contraste entre o fundo e o objeto. Por exemplo: o operador do software seleciona um grande retângulo em uma área externa da ferida a qual possui um brilho intenso decorrente do reflexo de uma fonte de luz. O operador seleciona ainda dois pequenos retângulos, referentes às duas amostras restantes, em uma área externa da ferida onde a iluminação é uniforme e a cor média reflete bem a cor referente a essa região. Se a média do fundo for calculada considerando as três amostras como sendo uma única imagem, a média resultante se aproximaria da primeira amostra, pois essa possui uma quantidade amostral bem maior que a das duas últimas seleções. Com isso, o resultado final da média do fundo se distanciaria da média real. Como a média final do fundo é obtida através das médias de cada amostra, casos como o descrito não influenciarão tanto, pois as três amostras terão o mesmo peso no resultado final. Em termos gerais a média do fundo é calculada através da equação 4.2 onde MF_j representa a média do fundo do j -ésimo canal e $\overline{A_i^j}$ a média da i -ésima amostra do j -ésimo canal.

$$MF_j = \frac{1}{N} \sum_{i=1}^N \overline{A_i^j} \quad (4.2)$$

A média da ferida, ou do objeto que se deseja segmentar, é obtida calculando a média dos pixels dentro do retângulo selecionado pelo usuário.

Tanto no caso da média do fundo, como da média do objeto, o cálculo dessas médias é realizado independentemente em cada um dos 6 (seis) canais avaliados.

4.2.1.2. Contraste

O contraste tem a finalidade de determinar o canal que possui maior poder discriminante entre a ferida e o fundo. Quanto maior for o contraste, mais facilmente a ferida será segmentada. O cálculo do contraste é facilmente obtido através da diferença entre a média do fundo e a média da ferida. Quanto maior a diferença, maior o contraste entre as duas regiões da imagem. Na equação 4.3 MF_j refere-se à média do fundo do j -ésimo canal, enquanto que MO_j refere-se à média do objeto, ou da ferida, também do j -ésimo canal. De forma equivalente ao cálculo das médias, o do contraste é executado sobre todos os 6 (seis) canais.

$$\text{Contraste}_j = |MF_j - MO_j| \quad (4.3)$$

4.2.1.3. Desvio Padrão

O desvio padrão [SPIEGEL, 1969] é utilizado para quantificar a variação da iluminação do fundo e do objeto. Quanto menor a variância, maior é a homogeneidade da região avaliada. Portanto, o canal com as melhores características é aquele que possuir maior contraste entre a ferida e o fundo e maior homogeneidade em ambos. Em relação às amostras externas da ferida, o desvio padrão leva em consideração a variância da média de cada amostra em relação à média do valor médio de todas as amostras. O desvio padrão da amostra interna é calculado normalmente, ou seja, o valor da variância de cada ponto em relação à média da amostra. Um detalhe interessante que deve ser citado, é o caso do exemplo dado em alguns parágrafos anteriores, quando é selecionada na imagem, uma amostra que não representa bem a média de cores da região externa. Nesse caso, o desvio padrão indicará uma alta variância no canal onde essa diferença é mais pronunciada.

Depois de calculada a média interna e externa da úlcera, o contraste e o desvio padrão de cada canal, o algoritmo divide o valor do contraste pelo valor do desvio padrão da amostra externa. O resultado dessa divisão é novamente dividido pelo desvio padrão da amostra interna, sendo que esse último valor calculado refere-se ao valor final do contraste, que será utilizado pelo algoritmo para classificar o melhor canal. Esse procedimento é realizado em todas os canais com seus respectivos valores. O canal que obteve bom contraste, mas um desvio padrão muito alto, seja esse desvio referente à amostra interna, seja esse desvio referente às amostras externas, ou ambas, terá uma redução desse contraste proporcional à homogeneidade nessas regiões. Por outro lado, o canal que obteve um contraste razoável acompanhado de baixos valores referentes a seus desvios padrões, terá boas chances de ser escolhido pelo algoritmo. Dos seis canais submetidos ao algoritmo discutido, será escolhido aquele que, no fim das operações, contiver o maior valor de contraste.

4.2.2. Algoritmos de Segmentação

Foram avaliados neste trabalho três algoritmos de Limiarização Adaptativa (Adaptive Threshold): seleção interativa, método de Niblack e método de Otsu.

4.2.2.1. Seleção Interativa

Esse método é baseado nos valores da média do objeto e média do fundo [PEREZ, 2.001a]. Aqui, os valores das médias são os mesmos utilizados pelo algoritmo que seleciona o melhor canal para a segmentação. O valor do limiar é obtido somando as duas médias e dividindo por 2 (dois), Eq. 4.4. A desvantagem dessa técnica é que ela depende das regiões selecionadas pelo usuário. Amostras extraídas de regiões diferentes da

mesma imagem, provavelmente produzirão médias diferentes, produzindo diferentes valores de limiar para a mesma imagem.

$$T = \frac{MF + MO}{2} \quad (4.4)$$

4.2.2.2. Método de Niblack

O propósito desse método é variar o limiar sobre a imagem, baseado na média e no desvio padrão local de um janelamento de $N \times N$ [TRIER, 1995]. Esse método, entretanto, não se demonstrou eficiente nas imagens de úlcera aplicando a limiarização local. Por essa razão, foi utilizado para calcular o valor de limiar, a média e o desvio padrão global da imagem, o qual demonstrou melhores resultados. O valor do limiar é obtido pela equação 4.5. Nessa equação m e s representam a média e o desvio padrão da imagem; a variável k é utilizada para ajustar o quanto da borda total do objeto é considerado como sendo parte do mesmo. Para os testes com as imagens, um valor de $k=0.05$ apresentou bons resultados.

$$T = m + k.s \quad (4.5)$$

4.2.2.3. Método de Otsu

No método proposto por Otsu, a segmentação de uma imagem em tons de cinza para uma imagem binária é considerada como um problema de classificação, onde duas classes são geradas a partir do conjunto de pontos contidos na imagem [WEEKS, 1996]. A primeira classe define o conjunto de pixels com níveis de cinza igual ou abaixo do valor do limiar K , enquanto que a segunda classe define o conjunto de pixels com valores acima do limiar K . O primeiro passo para implementar o método, é computar o histograma $h(G_i)$ da imagem que será binarizada. As equações 4.6, 4.7, 4.8, 4.9 e 4.10 são calculadas para cada valor de K variando de 1 até G_{max-1} . Nas equações

abaixo, G_{max} representa o nível máximo de cinza na imagem. O valor do limiar que representa a máxima variância entre as duas classes, Eq. 4.10, é escolhido como o valor ótimo de "Threshold".

$$m_1(K) = \sum_{i=0}^K i.h(G_i) \quad (4.6) \quad m_2(K) = \sum_{i=K+1}^{G_{max}-1} i.h(G_i) \quad (4.7)$$

$$P1(K) = \sum_{i=0}^K h(G_i) \quad (4.8) \quad P2(K) = \sum_{i=K+1}^{G_{max}-1} h(G_i) \quad (4.9)$$

$$\sigma^2 = \frac{[m_1(K).P2(K) - m_2(K).P1(K)]^2}{P1(K).P2(K)} \quad (4.10)$$

Dos três métodos de limiarização avaliados, o algoritmo de Otsu foi o que apresentou os melhores resultados para segmentar as imagens de úlcera de perna.

4.2.3. Algoritmo de Abertura

Após a binarização, determinados "objetos" da imagem resultante, os quais geralmente situam-se em regiões periféricas à ferida, sobrepunham-se sobre sua área. Essa sobreposição deve-se a pequenas regiões de pixels, ao redor da ferida, que possuem intensidade, ou níveis de cinza, próximos ao da úlcera. Essa sobreposição de objetos deve ser eliminada, uma vez que apenas a área da úlcera é de interesse. Para eliminar totalmente, ou parcialmente tal sobreposição, é utilizado o algoritmo de abertura (*Opening*) [RUSS, 1994], [PARKER, 1994], [LOW, 1991] e [SONKA, 1995], que é uma combinação dos algoritmos de erosão e dilatação, aplicados nessa seqüência. Os dois algoritmos, erosão e dilatação, são considerados duas operações básicas da morfologia matemática. A morfologia matemática é a ciência da forma e da

estrutura [LOW, 1991]. Em visão computacional, ela está relacionada com regiões e formas - como elas podem ser modificadas e contadas, e como suas áreas podem ser avaliadas. Uma abordagem mais profunda sobre morfologia matemática pode ser consultada em [MATHERON, 1975] e [SERRA, 1982].

O algoritmo de erosão tem o propósito de remover, ou "corroer", pixels de determinadas regiões que se localizam nas bordas desses objetos. Dessa forma, a área dos objetos, ou regiões, do primeiro plano, diminuem de tamanho e os "buracos" dentro dessas regiões aumentam.

Uma operação morfológica ϕ é dada pela relação de uma imagem X com um conjunto de pontos B chamado elemento estruturado. O elemento estruturado B possui uma origem local chamada ponto representativo. A transformação morfológica $\phi(X)$ aplicada sobre a imagem X significa que o elemento estruturado B é movido sistematicamente sobre a imagem. Assumindo que B está posicionado em determinado ponto da imagem, o pixel da imagem X correspondente ao ponto representativo de B é chamado **ponto corrente** (pixel que está sendo processado). O resultado da relação, que pode ser 0 (zero) ou 1 (um), entre a imagem X e o elemento B situado em determinada parte da imagem é armazenado na posição do **ponto corrente** [SONKA, 1995]. Na prática, o valor 1 é muitas vezes substituído por 255.

Tanto a operação de erosão como a de dilatação foram realizadas utilizando um elemento estruturado com uma dimensão de 3x3. Os valores desse elemento também são importantes para realização da operação. Nesse caso os valores representam a intensidade que terão os objetos da imagem. O valor para o fundo é representado por 0 (zero). O elemento estruturado da Figura 4.3 foi utilizado tanto pela operação de erosão como pela operação de dilatação, as quais aplicadas nessa ordem resultam em uma operação de abertura.

255	255	255
255	255	255
255	255	255

Figura 4.3 – Elemento estruturado utilizado pelos operadores morfológicos erosão e dilatação. O elemento marcado com o círculo corresponde ao ponto representativo, ou origem.

A operação de erosão é realizada comparando cada elemento da estrutura com os pontos coincidentes da imagem. Se pelo menos um dos pontos não coincidir, o ponto corrente da imagem é substituído por 0 (zero). No caso da dilatação, se pelo menos um ponto da imagem coincidir com o valor de um elemento da estrutura, o ponto corrente é substituído pelo valor 255, que representa os objetos na imagem. A operação de abertura é ilustrada na Figura 4.4, onde nela pode ser visto o motivo pelo qual foi atribuído o nome “abertura” (*Opening*) a essa operação. Na imagem o único objeto existente foi quebrado em dois. Isso porque eles eram unidos por um único ponto, e a operação de abertura “abriu” uma falha entre eles [PARKER, 1994].



(a)



(b)

Figura 4.4 - (a) Imagem antes da operação de abertura. (b) Imagem após a operação de abertura.

4.2.4. Rotulação

O algoritmo de rotulação [FISHER, 2000] tem o propósito de identificar cada objeto da cena atribuindo-lhe um rótulo, que geralmente é um número. Os pixels de um objeto rotulado terão o mesmo valor do rótulo atribuído a ele, e cada objeto é identificado por um rótulo de valor diferente. É importante que os objetos da cena estejam desconectados uns dos outros, pois se houver um pixel que faça a ligação entre dois objetos, o algoritmo pode considerá-los como sendo um objeto só. O algoritmo de abertura tem um papel muito importante nesse sentido, e é muitas vezes utilizado antes da rotulação dos objetos da imagem.

Após a rotulação, a área da imagem referente à úlcera é mantida enquanto que os demais objetos são eliminados. Determinar qual é o rótulo do objeto de interesse pode não ser uma tarefa tão simples. Umbaugh e Hance [HANCE, 1996] utilizam técnicas de momentos para identificar o rótulo da região de interesse em imagens segmentadas de câncer de pele. Felizmente neste trabalho identificação é bem mais simples. É utilizada a região retangular de dentro da ferida selecionada manualmente pelo operador do software no início da segmentação. O rótulo da ferida é aquele que estiver contido dentro desse retângulo cujo valor não seja zero, que seria o rótulo do fundo da imagem.

O algoritmo de rotulação utiliza duas imagens, a imagem segmentada e a imagem que conterá os objetos rotulados. Esse algoritmo percorre a imagem analisando a vizinhança de pixels, ilustrada na Figura 4.5, apenas quando o **ponto corrente é igual a 255**. Quando essa afirmação é verdadeira, ele compara os pontos da vizinhança para descobrir se algum ponto vizinho possui valor 255 também, indicando que aquele ponto pertence a algum objeto. Se houver algum ponto com valor 255 na vizinhança, o rótulo desse ponto é então atribuído na posição do ponto corrente na imagem de rótulos. Esse processo é repetido em toda a imagem. Após atribuir os rótulos nos

pontos processados, o algoritmo percorre novamente a imagem procurando por rótulos diferentes no mesmo objeto. Isso pode ocorrer com objetos curvos ou com concavidades. Por exemplo, os rótulos da letra U em uma imagem terão valores diferentes nos dois extremos da letra. O algoritmo só para de procurar rótulos diferentes quando não houver mais nenhuma troca.

x-1	x
y-1	y-1
x-1	X,Y
y	

Figura 4.5 – Operando utilizado pelo algoritmo de rotulação.

4.3. Algoritmo de Segmentação

Todos os passos descritos acima compõem o algoritmo de segmentação aplicado nas imagens de úlcera de perna. Cada um dos passos resumidos do algoritmo e seus resultados parciais podem ser visto na Figura 4.6.

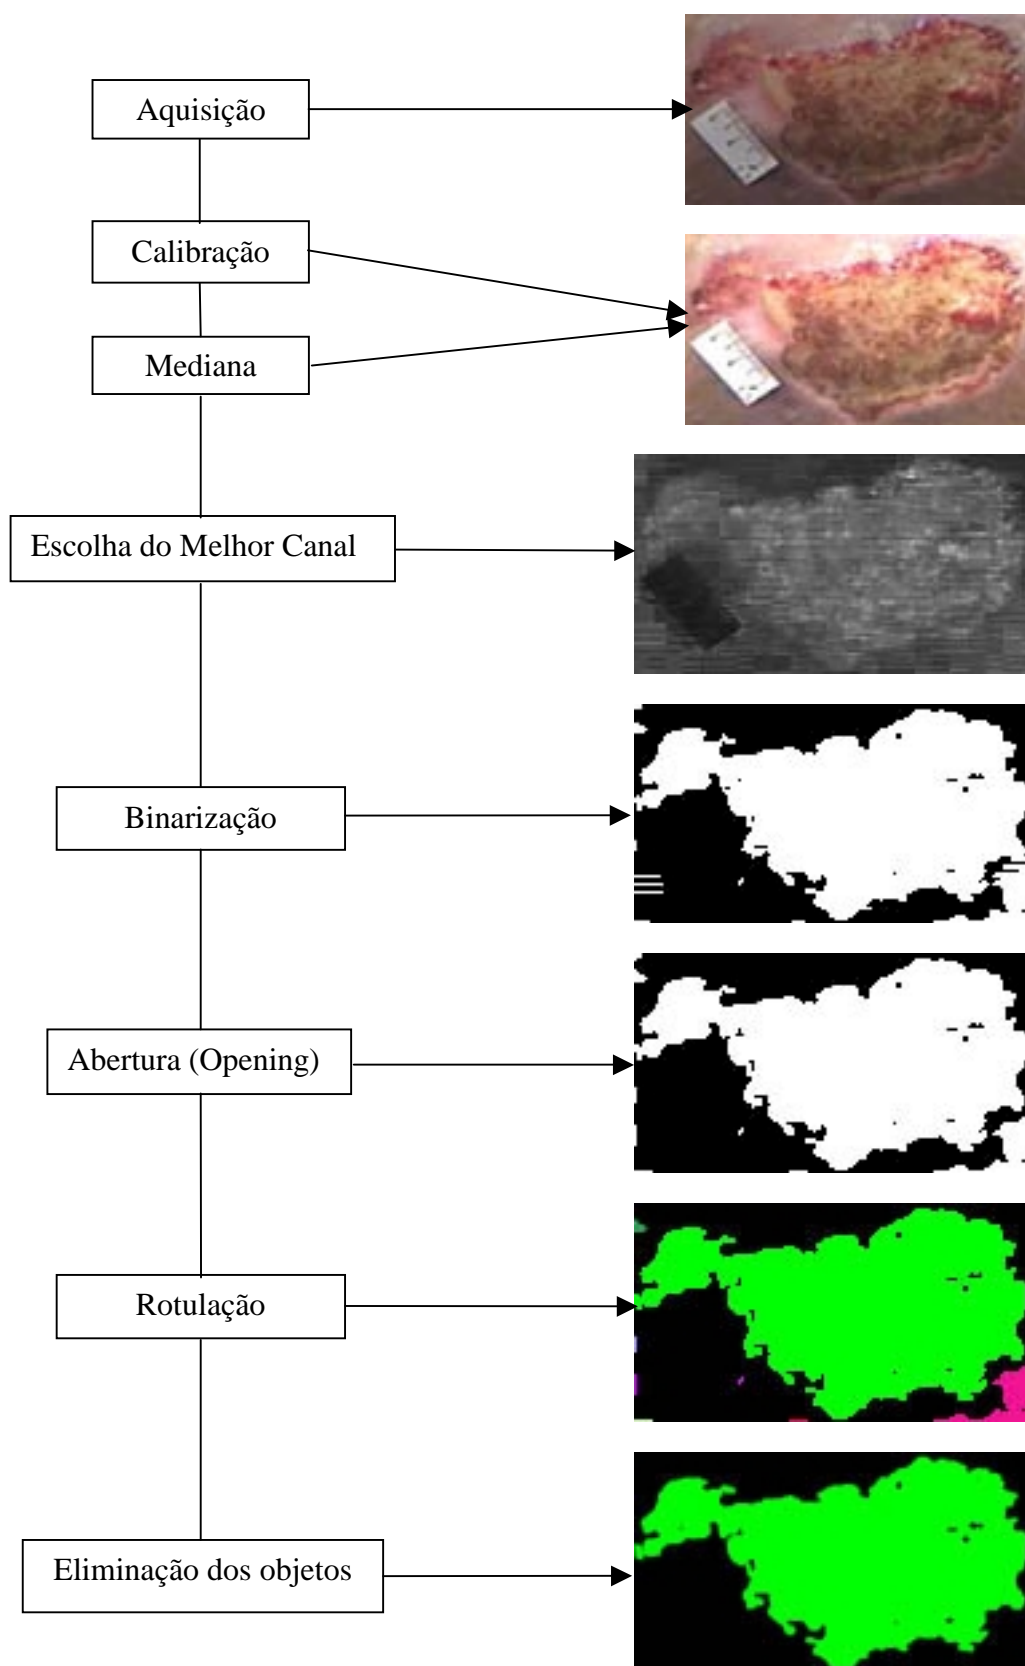


Figura 4.6 – Fluxo das tarefas realizadas pelo algoritmo de segmentação. Ao lado, imagens com os resultados parciais de cada passo.